

基于UKF的神经网络自适应全局信息融合方法

马 野,王孝通,戴 耀

(大连舰艇学院航海系,辽宁大连 116018)

摘 要: 为了解决神经网络(NN)在数据融合过程中权值实时更新问题,依据神经元激活函数的非线性特点,提出了一种利用Unscented卡尔曼滤波(UKF)实现神经网络权系数自适应调整的模式及方法,从而使全局融合信息最优。并分别以仿真数据及 DGPS/GPS/RLC/罗经等设备组成的舰船导航系统实测数据为例,首先对各局部滤波器进行UKF滤波,然后分别利用神经网络卡尔曼滤波(NNKF)及神经网络非线性卡尔曼滤波(NNUKF)进行数据融合,仿真和试验结果表明,所提方案对提高整个系统的精度和运算速度是行之有效的。

关键词: 信息融合; UKF; 神经网络; 组合导航; 信息分配

中图分类号: O211.64 **文献标识码:** A **文章编号:** 0372-2112(2005)10-1914-03

Study on Nonlinear Optimal Estimation for Neural Networks Data Fusion

MA Ye, WANG Xiaotong, DAI Yao

(Dalian Naval Academy, Dalian, Liaoning 116018, China)

Abstract: A new model and algorithm to realize adaptive adjustment of the weights of NN and to make global fusion information optimal were presented. The method utilizes Unscented Kalman filter (UKF) for nonlinear optimal estimation to solve the problem that weights of neural networks are not be on line trained in data fusion. Applies the above project to a multi sensors vessel integrated navigation system, obtains actual data from the integrated navigation system of DGPS/GPS/RLC/compass. First, using UKF methods estimates and filters the location information, then, NNKF and NNUKF are used to fuse them. The results of experiment and simulation show that the proposed approach is very useful for improving the accuracy and calculation speed of the system.

Key words: data fusion; Unscented Kalman filter; neural networks; integrated navigation; information allotment

1 引言

信息融合是根据一定准则对来自不同传感器的数据信息,加以筛选、分析和处理,从而全面而准确地描述被测对象。近年来,随着神经网络技术迅猛发展,使其在数据融合领域得到了广泛的应用^[3,4]。文献[1]提出了利用神经网络进行状态融合的方法,但所提方案仅限于离线训练网络,然后在线应用。事实上,在高动态的环境中,各局部信息在不断变化,如果网络权值不变,将会影响全局信息融合精度。为了适应这种变化,本文提出了非线性最优估计在神经网络数据融合中的应用模型,使整个系统既具有神经网络拟合效果好,又具有卡尔曼滤波实时估计能力强等特点。本文主要研究了UKF^[5,6]在舰船组合导航中的应用,及一种基于UKF的多层神经网络实时数据融合学习算法,使各局部传感器信息在经过UKF滤波后,自适应融合,达到最优估计的目的。通过仿真及实船数据验证,同时与文献^[1,2]提出的方法相比较,实验结果表明,该方案对提高整个系统的精度和运算速度是行之有效的。

2 模型研究

基于非线性最优估计^[7,8]的神经网络数据融合方法,是依据先分散处理,再全局融合的思想,对各局部信息进行有效的数据融合。各传感器信息通过局部滤波器获得局部最优状态估计值,每个局部滤波器并行工作,然后利用全局融合系统进行信息综合、实时校正、顺序处理,给出全局最佳状态估计。

根据文献[1],得到极大似然估计 $X_f(k)$ 及协方差为 P_v , $X_f(k)$ 为可简化为:

$$X_f(k) = WX_i(k) \quad (1)$$

式(1)与神经网络工作方式相似,因此可以用神经网络代替式(1)的信息融合过程,式中, W 为神经网络的权矢量, $X_i(k)$ 为输入矢量。利用这种方法,可以不必估计各局部滤波器的状态协方差,只需估计神经网络的权重即可。

神经网络把来自各子系统包括外部传感器1、传感器2、……、传感器 N 的状态估计进行融合,通过离线训练网络确定稳定状态下网络的权值。由于各局部滤波器的输出是不断变化的,为了保证全局状态估计最优,同时对神经元激活函数非线性特点,本文利用UKF在线调整网络权值,使其适应各局部状态的变化。神经网络UKF卡尔曼滤波数据融合模型如图1所示。




图1 非线性最优估计神经网络数据融合模型

3 融合算法

3.1 神经网络状态方程

假设1 第 n 层神经元个数为 N ,由第 n 层的第 j 个神经元输入到第 $n+1$ 层的第 i 个神经元的连接权系数为 w_{ji}^n ,阈值为 θ_i^n 。

假设 2 各神经元非线性变换函数 $f(\cdot)$, 采用 sigmoid 函数, 即: $f(x_i^{n+1}(k)) = 1/(1 + \exp(-x_i^{n+1}(k)))$ (2)

定义 1 根据假设 1 假设 2, 神经网络的输入输出变换关系为:

$$x_i^{n+1}(k) = f\left(\sum_{j=1}^N w_{ij}^n x_j^n(k) + \theta_i^n\right) = f\left(\sum_{j=1}^{N+1} w_{ij}^n x_j^n(k)\right) \quad (3)$$

如果把网络的连接权作为状态向量, 目标输出向量作为观测值, 由(3)式可以写出神经网络非线性状态方程:

$$\begin{aligned} W(k+1) &= W(k) + \eta(k) \\ Z(k) &= f(W(k), X_j(k)) + v(k) \end{aligned} \quad (4)$$

其中, $W(k) \in R^n$ 为系统状态向量, $Z_f(k) \in R^n$ 观测值, $X_j(k)$ 为系统输入矢量, 系统噪声观测噪声 $\eta(k)$ 、 $v(k)$ 分别为高斯白噪声序列, 其均值为零, 方差阵分别为 Q_1 , R_1 .

式(4)为非线性状态方程, 无法采用标准卡尔曼滤波进行状态估计. 对于此非线性系统, 本文采用 Unscented 卡尔曼滤波(UKF)进行滤波.

3.2 在线滤波算法

以稳定后的神经网络权值为 UKF 的状态初始值, 首先进行时间更新. 设 N 维状态变量 w_k , 其均值为 $w_{k/k}$, 协方差为 $P_{k/k}$, 本文将其分解成 $2n+1$ 维的散布形式, 即:

$$\begin{aligned} x_{00} &= w_{k/k}, q_0 = k/(n+k) \\ x_{1i} &= w_{k/k} + \left[\sqrt{(n+k)P_{k/k}} \right]_i, q_{1i} = 1/2(n+k) \\ &\quad i = 1, \dots, 2n \\ x_{i+n} &= w_{k/k} - \left[\sqrt{(n+k)P_{k/k}} \right]_i, q_{i+n} = 1/2(n+k) \\ &\quad i = n, \dots, 2n+1 \end{aligned} \quad (6)$$

其中, $k \in R$, 为一比例因子, $\left[\sqrt{(n+k)P_{k/k}} \right]_i$ 为加权相关矩阵平方根阵的第 i 列, q_i 是第 i 个点的加权系数. 给出这些西格马点集后, 可以对状态变量及协方差进行预测, 方法为:

$$\begin{aligned} \hat{w}(k+1/k) &= \sum_{i=0}^{2n} q_i x_i(k+1/k) \\ P(k+1/k) &= \sum_{i=0}^{2n} q_i [x_i(k+1/k) - \hat{w}(k+1/k)] \\ &\quad \times [x_i(k+1/k) - \hat{w}(k+1/k)]^T \end{aligned} \quad (7)$$

由于观测方程是非线性的, 可以计算出根据西格马点集分布的各观测值及观测估计值:

$$Z_i(k+1/k) = f(x_i(k+1/k), k) \quad (8)$$

$$\hat{z}(k+1/k) = \sum_{i=0}^{2n} q_i Z_i(k+1/k) \quad (9)$$

测量更新:

$$\begin{aligned} P_w(k+1/k) &= \sum_{i=0}^{2n} q_i [x_i(k+1/k) - \hat{w}(k+1/k)] \\ &\quad \times [x_i(k+1/k) - \hat{w}(k+1/k)]^T \end{aligned} \quad (10)$$

$$\begin{aligned} P_{xv}(k+1/k) &= \sum_{i=0}^{2n} q_i [x_i(k+1/k) - \hat{w}(k+1/k)] \\ &\quad \times [Z_i(k+1/k) - \hat{z}(k+1/k)]^T \end{aligned} \quad (11)$$

$$K_k = P_{xv} P_{vv}^{-1} \quad (12)$$

$$\hat{w}_k = \hat{w}(k+1/k) + K_k(z(k) - \hat{z}(k)) \quad (13)$$

$$P(k+1) = P(k+1/k) - K_k P_{vv} K_k^T \quad (14)$$

4 应用实例

4.1 仿真实验

取航速作机动变化的舰艇为仿真模型. 通过观测舰艇距离, 分别求出距离与速度估计值 $\hat{x}_1(k/k)$ 和 $\hat{x}_2(k/k)$.

设对象的基本数学模型为:

$$\begin{bmatrix} x_1(k+1) \\ x_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & \Delta t \\ 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} \frac{1}{2} \Delta t^2 \\ \Delta t \end{bmatrix} a_k$$

其中, a_k 为随机的时变加速度, Δt 为 $k+1$ 与 k 时刻的时间间隔. 本文假设能够观测到舰艇位置 x_1 , 那么, 在 k 时刻的测量方程可以表示为: $z(k) = x_1(k) + v_k$, v_k 为随机测量噪声. 并进一步假设过程噪声 w_k 是方差为 Q 的高斯白噪声, 测量噪声 v_k 是方差为 R 与 Q 不相关的高斯白噪声.

$$w(k) = \begin{bmatrix} \frac{1}{2} \Delta t^2 \\ \Delta t \end{bmatrix} R(k) = E[v(k)v(k)^T]$$

$$Q(k) = E[w(k)w(k)^T] = \begin{bmatrix} \frac{1}{4} \Delta t^4 & \frac{1}{2} \Delta t^2 \\ \frac{1}{2} \Delta t^2 & \Delta t^2 \end{bmatrix}$$

$$\text{状态转移阵为: } \Phi = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix};$$

$$\text{测量矩阵: } H(k) = [1 \ 0];$$

仿真初始参数选取为:

- (1) 位置真值: $x_k = 3 \sin(t_k)$;
- (2) 位置测量噪声的方差为 10m ;
- (3) 加速度过程噪声标准偏差 0.5m/s^2 ;
- (4) 时间间隔为 0.2s ;
- (5) 仿真时间为 200s .

以分析的数学模型为基础, 利用图 1 的方法, 分别建立含有不同模型误差和观测误差的两种传感器模型, 然后进行局部估计、全局融合、在线自适应学习等处理. 本文对局部状态估计结果、仅用神经网络进行融合结果^[1]及利用非线性最优估计在线学习结果进行比较, 其距离真值、估计值的输出曲线如图 2 所示.




图 2 仿真曲线

4.2 实测数据实验

以 DGPS/GPS/RLC/罗经等导航设备组合, 进行实船试验. 建立状态模型, 利用该算法进行验证.

选择舰船导航系统的状态矢量分量分别为: $x_1 = \varphi$ (纬度弧长), $x_2 = \lambda$ (经度弧长), $x_3 = V_{CE}$ (海流东向分量), $x_4 = V_{CN}$ (海流北向分量), $x_5 = V$ (航速), $x_6 = H$ (航向), $x_7 = \Omega$ (舰船角速度变化量). 如果假定经纬度误差足够小, 以至于平坦地球动态的近似值对于舰船的正常位置是正确有效的. 那么状态矢量的轨迹状态向量 X 为:




图3 航迹曲线仿真

$$\begin{cases} \varphi(k) = \varphi(k-1) + (1 - e^{-\beta_c T}) / \beta_c V_{CN}(k-1) - V(k-1) \\ \quad \times \cos(H(k-1) + T/2 \cdot \Omega(k-1)) \cdot T + w_1(k-1) \\ \lambda(k) = \lambda(k-1) + (1 - e^{-\beta_c T}) / \beta_c V_{CE}(k-1) - V(k-1) \\ \quad \times \sin(H(k-1) + T/2 \cdot \Omega(k-1)) \cdot T + w_2(k-1) \\ V_{CE}(k) = e^{-\beta_c T} V_{CE}(k-1) + w_3(k-1) \\ V_{CN}(k) = e^{-\beta_c T} V_{CN}(k-1) + w_4(k-1) \\ V(k) = V(k-1) + w_5(k-1) \\ H(k) = H(k-1) + \Omega(k-1) \cdot T + w_6(k-1) \\ \Omega(k) = \Omega(k-1) + w_7(k-1) \end{cases} \quad (15)$$

其中: 在洋流相关模型中, 隐含的假设是相关时间为: $1/\beta_c$, $\beta_c^{-1} = 15 \text{ nmile}/\text{航速}$. 式(15)中, $w_1 \sim w_7$ 为不相关的零均值白噪声, T 为采样时间间隔. 式(15)矩阵可描述为:

$$X(k) = f(X(k-1), k-1) + \Gamma W(k-1) \quad (16)$$

为了保证滤波器运行时间最短, 本文约定进入 UKF 的量测向量始终保持 4×1 维, 量测向量始终保持 4×1 维, 即:

$$\begin{cases} Z(k) = [\varphi_m(\text{纬度}), \lambda_m(\text{经度}), V_m(\text{航速}), H_m(\text{航向})]^T \\ \begin{cases} \varphi_m(k) = \varphi(k) + v_1(k) \\ \lambda_m(k) = \lambda(k) + v_2(k) \\ V_m(k) = V(k) + v_3(k) \\ H_m(k) = H(k) + v_4(k) \end{cases} \end{cases} \quad (17)$$

系统的量测方程为: $Z(k) = H(k)X(k) + V(k)$

其中, 状态矩阵 $X(k) \in R^n$, 观测向量 $Z(k) \in R^m$, 观测噪声 $V(k)$ 为随机独立高斯白噪声序列, 其均值为零, 方差阵 R , $H(k)$ 为常数阵.

综上, 离散的非线性系统描述为:

$$\begin{cases} X(k) = f(X(k-1), k-1) + \Gamma W(k-1) \\ Z(k) = H(k)X(k) + V(k) \end{cases} \quad (18)$$

针对非线性方程, 利用 UKF 局部滤波器进行局部最优估计, 然后, 以 DGPS 的定位信息为标准, 采用公式(2)~(14), 分别利用神经网络 UKF(NNUKF) 方法和神经网络 KF(NNKF) 方法, 在线估计神经网络权值, 融合各滤波器信息. 这里, NNUKF 采用 bp 网络非线性 UKF 方法在线调整权值; NNKF 为线性网络, 标准卡尔曼滤波在线调整权值. 仿真结果表明, NNUKF 方法拟合精度更高. 图3 为实际数据航迹曲线, 分别给出了局部滤波器估计值、NNUKF 融合值及 NNKF 融合值曲线.

5 结论

通过本文的讨论及仿真和实验结果表明, 非线性最优估计与神经网络技术相结合, 可以有效地解决信息融合实时性问题. 这种方法不必计算各误差方差及其逆矩阵, 大大缩减了

计算量. 同时, 利用 Unscented 卡尔曼滤波对神经网络权值在线调整, 可以灵活有效地分配各局部信息, 使全局融合信息最优或近似最优. 将该方案应用到组合导航系统中, 并与其他算法进行比较, 理论分析和实验结果表明, 所提出的模型及自适应训练方法对提高整个系统的精度和运算速度都是行之有效的.

参考文献:

- [1] Chowdhury F N. A Neural approach to Data Fusion [A]. Proc. American control Conf [C]. USA: Seattle, WA, 1995. 1693-1697.
- [2] 陶俊勇. 组合导航系统的神经元信息融合模型[J]. 国防科技大学学报, 2002, 24(3): 81-85.
Tao Jun yong. Information fusion model of integrated navigation system base on neurons [J]. Journal of National University of Defense Technology, 2002, 24(3): 81-85. (in Chinese)
- [3] 权太范. 信息融合神经网络-模糊推理理论与应用[M]. 北京: 国防工业出版社, 2002.
Taifan Quan. Information Fusion Theory and Application Based on NN-FR Technology [M]. Beijing: National Defence Industry Press, 2002. (in Chinese)
- [4] Simon Haykin. Neural Networks: A Comprehensive Foundation [M]. 2nd Edition. USA: Prentice Hall PTR, 1998.
- [5] S J Julier, J K Uhlmann. A new Extension of the Kalman filter to Nonlinear Systems [A]. In Proceedings of the SPIE Aero sense International Symposium on Aerospace/Defense Sensing, Simulation and Controls [C]. Orlando, Florida: April, 1997. 20-25.
- [6] E Awan, A T Nelson. Neural dual extended Kalman Filtering: applications in speech enhancement and monaural blind signal separation. In Proc of IEEE Workshop on Neural Networks for Signal Processing VII [C]. Florida: September 1997.
- [7] S J Julier. The scaled unscented transformation [J]. In Proceedings of American Control Conference, Anchorage, AK, USA, May 2002, 6: 4555-4559.
- [8] J K Uhlmann. Algorithms for multiple target tracking [J]. American Scientist, 1992, 80(2): 128-141.
- [9] Krakiwsky E J, Harris C B, Wang R V C. A Kalman Filter for Integrating Dead Reckoning, Map Match and GPS Position [A]. Proceedings of IEEE Position, Location and Navigation Symposium [C]. USA, Orlando: Institute of Navigation, 1988. 39-46.

作者简介:



马野女, 1966年12月生于德惠, 大连舰艇学院自控教研室副教授、博士生, 主要研究方向: 控制理论、神经网络模型及应用、智能控制、组合导航等. E-mail: anewday_021004@163.com.

王孝通 男, 1962年出生于义乌, 大连舰艇学院航海系主任、教授、博士生导师, 主要研究方向: 自动控制与导航工程.